

文章编号: 1000-8055(2009)06-1420-06

最小二乘支持向量回归机在发动机推力估计中的应用

赵永平, 孙健国

(南京航空航天大学 能源与动力学院, 南京 210016)

摘 要: 实现直接推力控制的首要问题就是要估计出推力. 基于最小二乘支持向量回归机提出了一种 Wrapper 算法进行特征选择, 此算法不仅能降低计算的复杂度, 而且能增强模型的泛化能力. 另外, 在对最小二乘支持向量回归机进行稀疏性建模的时候, 用 QR 分解法代替传统的协方差法, 增强了数值的稳定性. 最后, 推力估计器设计的应用实例, 验证了本文提出的特征选择法和 QR 分解法进行稀疏性建模的可行性和实用性.

关 键 词: 推力估计; 最小二乘支持向量回归机; 特征选择; wrapper 算法; QR 分解

中图分类号: V233.7

文献标识码: A

Aeroengine thrust estimation using least squares support vector regression machine

ZHAO Yong-ping, SUN Jian-guo

(College of Energy and Power Engineering,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: The first problem for direct thrust control is thrust estimation. A wrapper algorithm, which reduces the computational complexity and also enhances the model generalization performance, was proposed based on least squares support vector regression machine. In addition, as a surrogate of traditional covariance method, QR decomposition was utilized to build sparse model strengthening the numerical stability. Finally, a thrust estimator design was applied to validate the effectiveness and feasibility of the proposed feature selection algorithm and sparse model using QR decomposition.

Key words: thrust estimation; least squares support vector regression machine; feature selection; wrapper algorithm; QR decomposition

航空发动机传统的控制方式是基于传感器的液压机械式控制, 它以传感器的测量参数如风扇转速、压比作为反馈信号来设计控制器, 通过控制这些参数达到控制设计人员真正感兴趣的量, 如推力、稳定裕度等. 由于这种控制方式是使用间接的办法达到控制推力的目的, 故存在不精确的缺陷. 为了保护发动机, 在设计发动机时往往保留较

大的裕度, 这就在一定程度上降低了航空发动机的性能^[1]. 随着计算机技术的迅速发展, 航空发动机已普遍采用数字控制, 但目前的发动机数控系统仍然普遍采用上述基于传感器的方法, 数字控制的潜力没有得到充分发挥. 为了充分挖掘航空发动机机的潜在性能, 有必要实现航空发动机的直接推力控制^[2]. 要实现航空发动机的直接推力

收稿日期: 2008-06-18; 修订日期: 2008-12-27

基金项目: 国家自然科学基金(50576033); 航空科学基金(04C52019)

作者简介: 赵永平(1982-), 男, 河南南阳人, 博士生, 研究方向为航空发动机控制. E-mail: y. p. zhao@nuaa.edu.cn

控制面临的首要难题就是要准确地估计出当前航空发动机的推力, 如果估计出的推力不准确, 那么实现直接推力控制就失去了意义, 也就是说要设计一个高精度的推力估计器. 如果以航空发动机的可测参数作为输入量, 以推力为输出量, 那么就可以设计出一个推力估计器, 从而来实现航空发动机的直接推力控制. 本文基于最小二乘支持向量机, 并提出一些改进算法来设计推力估计器.

支持向量机是由 Vapnik 等^[3]提出的一种基于统计学理论和结构风险最小化原则的机器学习方法. 和传统的机器学习方法如神经网络相比较, 它有良好的泛化能力和不陷入局部最优解的优势. 在建立支持向量机的过程当中, 由于要实现二次优化求解, 因而其训练代价比较高. 为了降低计算的复杂度, Suykens 等^[4]提出了最小二乘支持向量机, 它用等式约束代替不等式约束, 最后归结为求线性方程组, 大大降低了计算的代价, 因而深受欢迎而被得到广泛的应用. 但和支持向量机相比较, 其解存在缺乏稀疏性的缺陷. 为了实现最小二乘支持向量解的稀疏性, 人们提出了很多实现其解稀疏性的方法, 其中很重要的一类是剪枝算法^[5], 它按照一定的剪枝标准在建模过程当中不断修剪训练数据以达到实现解的稀疏性目的.

在推力估计器设计中必然要解决合理选择输入量的问题, 特征选择 (Feature selection) 是解决此问题的有力手段. 特征选择无论在模式识别还是在函数回归方面都是一个值得研究的方面, 因为不相关的特征或者冗余的信息不仅会影响到分类器和回归机计算复杂度, 还会对泛化能力产生影响. 由于特征选择是一个 Non-deterministic Polynomial (NP) 难问题, 用穷举搜索方法是不现实的. 常见的特征选择方法一般可以分为两大类^[6]: ①Filter 法, 这种方法在选择特征的时候独立于分类器和回归机进行选择; ②Wrapper 法, 这种方法在选择变量的时候考虑到分类器和回归机的泛化性能. 一般来说, Filter 法执行的效率比较高, 但用它选择的特征来设计分类器和回归机的泛化性能不及 Wrapper 法. 目前, 特征选取的研究主要集中在分类器设计方面, 相反关于回归机的特征选择问题研究得比较少. 因此, 本文基于最小二乘支持向量回归机提出了一种特征选择方法, 此法属于 Wrapper 法, 它在特征选择的过程当中考虑到了回归机的泛化性能. 另外, 为了增加稀疏最小二乘支持向量回归机建模的数值稳定性, 本文用 QR 分解法代替传统的协方差方法增

加了数值的稳定性. 最后, 将本文提出的特征选择方法和稀疏最小二乘支持向量回归机结合起来设计了一个推力估计器, 数字仿真结果表明此推力估计器能满足航空发动机直接推力控制的要求.

1 最小二乘支持向量回归机

给定一个训练数据集 $\{(\mathbf{x}_i, d_i)\}_{i=1}^N$, 其中 $\mathbf{x}_i \in \mathbf{R}^n$ 为系统的输入量, $d_i \in \mathbf{R}$ 为系统的输出量, 通过把不等式约束变成等式约束, Suykens 等提出了如下最小二乘支持向量回归机的数学模型:

$$\min_{\mathbf{w}, \mathbf{e}} J(\mathbf{w}, \mathbf{e}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{2} \sum_{i=1}^N e_i^2 \quad (1)$$

s. t. $d_i = \mathbf{w}^T \Phi(\mathbf{x}_i) + b + e_i, \quad i = 1, \dots, N$

其中 $C \in \mathbf{R}^+$ 是正则化因子, $\mathbf{e} = [e_1, \dots, e_N]^T$, $\Phi(\cdot)$ 是一个非线性映射能把 $\mathbf{x}_i$ 从输入空间映射到高维 (甚至无限维) 的特征空间从而实现在输入空间中的非线性回归转化为高维特征空间中的线性回归. 通过构造 Lagrange 函数可以把式 (1) 的约束优化转化为无约束优化

$$L(\mathbf{w}, b, \mathbf{e}; \boldsymbol{\alpha}) = J(\mathbf{w}, \mathbf{e}) - \sum_{i=1}^N \alpha_i [\mathbf{w}^T \Phi(\mathbf{x}_i) + b + e_i - d_i] \quad (2)$$

其中 $\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_N]^T$ 为 Lagrange 乘子. 由 Karush-Kuhn-Tucker (KKT) 条件可知

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{i=1}^N \alpha_i \Phi(\mathbf{x}_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = C e_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow \mathbf{w}^T \Phi(\mathbf{x}_i) + b + e_i - d_i = 0 \end{cases} \quad (3)$$

把 $\mathbf{w}$ 和 e_i 代入式 (2) 中可得如下线性方程组:

$$\begin{bmatrix} \Omega & \mathbf{I} \\ \mathbf{I}^T & 0 \end{bmatrix} \begin{bmatrix} \mathbf{d} \\ b \end{bmatrix} = \begin{bmatrix} \mathbf{d} \\ 0 \end{bmatrix} \quad (4)$$

其中 $\mathbf{d} = [d_1, \dots, d_N]^T$, $\mathbf{I} = [1, \dots, 1]^T$, $\Omega_{ij} = k(\mathbf{x}_i, \mathbf{x}_j) + \frac{\delta_{ij}}{C}$, $\delta_{ij} = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases}$, $k(\mathbf{x}_i, \mathbf{x}_j)$ 是核函数, 其中常见的核函数有多项式 $k(\mathbf{x}_i, \mathbf{x}_j) = [(\mathbf{x}_i, \mathbf{x}_j) + 1]^n$, 高斯型 $k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left[-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\gamma^2}\right]$ 等. 通过解方程组 (4) 可以得到如下回归机:

$$y = f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum_{i=1}^N \alpha_i k(\mathbf{x}_i, \mathbf{x}) + b \quad (5)$$

要建立式(5)的回归机,有两个问题需要解决.首先要确定训练数据 $\mathbf{x}_i$ 的维数,即要确定 $\mathbf{x}_i$ 的特征数,这在用高维数据进行建模的时候尤为重要,因为用不相关的特征或冗余信息来建模不仅增加了模型的复杂度,还可能影响到模型的精度或者泛化能力.另外,式(5)的回归机是非稀疏性的,这对预测是不利的,因为预测时间和支持向量的数目成正比,支持向量的数目越多,模型的预测时间越长.这在对预测时间要求比较高的场合实现回归机的稀疏性是非常必要的.针对这两个问题,下面采用一定的措施进行解决.

2 特征选择

由丑小鸭定理(Ugly duckling theorem)^[7]可知,不存在与问题无关的“优越”的或“最好”的特征集合或属性集合,也就是说不存在脱离问题的“优越”的特征,如果不放在特定的环境,各个特征或属性都是“平等”的.相反,若放在特定的环境中,各个特征或属性的差异也就表现了出来.如果要用一些特征进行特定问题的建模,当然要选择那些与问题有关的比较“优越”的特征或属性,抛弃那些不重要,甚至冗余的特征或属性.

交叉验证(Cross-validation)法^[7]是一种常用的模型选择方法,它可以使模型获得较好的推广性能.留一法(Leave one out)^[8]也叫 Jackknife 法是其中之一,其主要思想是逐次让训练数据集中的一个数据不参加建模,而用其余的数据来建立模型,然后用建立好的模型来预测那一个不参加建模的数据,最后根据预测的效果来决定模型.对于最小二乘支持向量回归机来说,有以下定理:

定理 1: 令 $\hat{d}_k$ 代表留一法中第 k 个数据的预测值, $\beta_k = d_k - \hat{d}_k$, 则有下式成立:

$$\beta_k = \frac{\alpha_k}{\mathbf{H}(k, k)}, \quad (k = 1, \dots, N) \tag{8}$$

其中 $\mathbf{H} = \begin{bmatrix} \Omega & \mathbf{I} \\ \mathbf{I}^T & 0 \end{bmatrix}^{-1}$, α_k 是式(4)的解.

关于定理 1 的证明可以参看文献[8]中定理 1 的证明,只是此定理的一个极限情况.令 $\mathbf{x}_k(i)$ 为 $\mathbf{x}_k$ 中第 i 个特征被剔除后的输入量, $i = 1, \dots, n$, $k = 1, \dots, N$. 由定理 1 可知, $\beta_k(i) = \frac{\alpha_k(i)}{\mathbf{H}(i)(k, k)}$. 令 $\beta(i) = [\beta_1(i) \dots \beta_N(i)]^T$, $\|\beta(i)\|$ 越小 ($\|\cdot\|$ 代表某种范数),说明第 i 个特征对模型的贡献越小,即若 $\|\beta(i)\| < \|\beta(j)\|$, 则说明第 i

个特征不如第 j 个特征对模型的贡献大.按照 $\|\beta(i)\|$ 的大小,可以剔除对模型贡献小的特征,从而实现对模型的特征选择.因此提出了下面的特征选择 Feature selection (FS) 算法:

FS 算法

- Step 1: 令 $P = \{1, \dots, n\}$, $S = T = \emptyset$, 定义一个正整数 M (要选择的特征个数);
- Step 2: 如果 $|P| \leq M$, 则程序结束, 其中 $|\cdot|$ 代表集合的势;
- Step 3: 计算 $S = \{\beta(i) \mid i \in P\}$;
- Step 4: 计算 $T = \{\|\beta(i)\| \mid \beta(i) \in S\}$;
- Step 5: 令 $i' = \arg \min_{i \in P} \|\beta(i)\|$, $P = P - i'$, 转到 Step 2.

等 FS 算法结束后,则集合 P 中即为要选的 M 个特征的索引.一般来说,这 M 个特征对模型的建立的贡献都是比较的,所以选择这 M 个特征来建立模型是比较合理的.由于 FS 算法在选择特征的过程中,考虑到了模型的泛化能力,故这是一种 Wrapper 方法.

3 稀疏性建模

当确定好建立模型要使用的特征变量后,接下来要做的就是开始建立模型.由式(5)可知,最小二乘支持向量回归机的数学模型是非稀疏性的,这在对模型预测时间要求比较高的场合是不适用的,故有必要将最小二乘支持向量回归机进行稀疏化.常用的一种稀疏化方法是剪枝算法,其中比较经典且比较容易理解和执行的是 Suykens 等提出的剪枝算法^[5].原剪枝算法采用完全抛弃的策略没有考虑到非支持向量对最小二乘支持向量回归机建模的贡献,故有一定不合理之处,其改进之处就是采取部分抛弃的策略^[9,10],当要剪掉第 i 个训练数据时,只删掉相应的列而保持相应的行,如式(9)中虚线所示

$$\begin{bmatrix} \Omega_{11} & \cdots & \overline{\Omega_{1i}} & \cdots & \Omega_{1N} & 1 \\ \vdots & & \vdots & & \vdots & \vdots \\ \Omega_{i1} & \cdots & \Omega_{ii} & \cdots & \Omega_{iN} & 1 \\ \vdots & & \vdots & & \vdots & \vdots \\ \Omega_{N1} & \cdots & \Omega_{Ni} & \cdots & \Omega_{NN} & 1 \\ 1 & \cdots & 1 & \cdots & 1 & 0 \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \vdots \\ \alpha_i \\ \vdots \\ \alpha_N \\ b \end{bmatrix} = \begin{bmatrix} d_1 \\ \vdots \\ d_i \\ \vdots \\ d_N \\ 0 \end{bmatrix} \tag{9}$$

当非支持向量被删掉后,式(9)变成了一个超定的线性方程组,简记为

$$\overline{\Omega} \alpha = \tilde{d} \tag{10}$$

其中式 (10) 常见的一种解法叫协方差法, 其解由“法方程”

$$\Omega^T \Omega \tilde{\alpha} = \Omega^T \tilde{d} \tag{11}$$

给出. 然而, 由于条件数 $\kappa[\Omega^T \Omega]$ 是 $\kappa[\Omega]$ 的平方, 因此, 直接计算 (11) 得到的解可能是严重病态的 (即条件数很大), 即使 $\kappa[\Omega]$ 并不大, 不是严重病态的. 这种情况在本文设计推力估计器的过程中就碰到过, 以致于设计出来的推力估计器根本就不可能用. 为了不增加式 (10) 的条件数, 同时也为了保持数值的稳定性, 本文给出了一种用 QR 分解法建立稀疏最小二乘支持向量回归机模型的方案. 首先将 Ω 进行 QR 分解

$$\Omega = QR \tag{12}$$

其中 Q 为正交矩阵, R 是一个上三角矩阵. 解式 (10) 相当于解如下优化问题:

$$\min_{\tilde{\alpha}} \|\Omega \tilde{\alpha} - \tilde{d}\|_2^2 \tag{13}$$

由于正交变换可以保持向量的长度或范数不变, 所以式 (13) 等价于式 (14):

$$\min_{\tilde{\alpha}} \|\tilde{Q} \tilde{\alpha} - \tilde{Q} \tilde{d}\|_2^2 = \|\tilde{R} \tilde{\alpha} - \tilde{Q} \tilde{d}\|_2^2 \tag{14}$$

通过解式 $R \tilde{\alpha} = Q \tilde{d}$ (15)

可以求得 $\tilde{\alpha}$. 由于 R 是上三角矩阵, 式 (15) 可以用向前回代法很容易地求解. 用 QR 分解法解式 (10) 不会增加求解过程的条件数, 保持数值的稳定性. 另外即使 Ω 不是列满秩矩阵, 也可以在最小二乘意义下很容易地用 QR 分解进行求解, 同时也可以很好地保持数值的稳定性. 下面给出用 QR 分解法建立稀疏最小二乘支持向量回归机 (Sparse least squares support vector regression machine) SLSSVM 数学模型的过程:

QR SLSSVM 算法

- Step 1: 基于训练数据集 $\{(\mathbf{x}_i, d_i)\}_{i=1}^N$ 建立最小二乘支持向量回归机的数学模型;
- Step 2: 按一定比例 (譬如 2%) 剪掉那些支持权重 $|\alpha|$ 比较小的训练数据;
- Step 3: 采用部分抛弃的策略, 用 QR 分解法在约简后的训练数据集上重新构建稀疏最小二乘支持向量回归机的数学模型;
- Step 4: 若事先定义的性能指标下降, 则结束; 否则转到 Step 2.

将 FS 算法和 QR-SLSSVM 算法相结合, 可以实现最小二乘支持向量回归机的特征选择和稀疏性建模.

4 全包线推力估计

本小节将使用前几节所提出的方法来设计航空发动机推力估计器, 由于在全包线内航空发动机的推力变化范围比较大, 同时又要求估计出来的推力精度比较高, 这就为设计推力估计带来了困难. 因此, 可以将全包线划分为几个区域, 然后在每一个区域设计一个子估计器, 最后根据当前的飞行状态选择合适的子估计器来估计当前航空发动机所提供的推力以达到实现直接推力控制的目的 (如图 1).




图 1 航空发动机的直接推力控制结构图
Fig.1 Block diagram of direct thrust control for aeroengines

本文以某型混合排气涡扇发动机非线性部件级模型 (如图 2 所示) 为研究对象设计一个全包线推力估计器. 针对此发动机模型, 总共有 45 个可测参数, 但不能将所有的可测参数都作为推力估计器的输入量, 主要有两点原因: ①航空发动机不允许装那么多传感器; ②太多的输入量 (可能存在冗余量) 会影响推力估计器的泛化能力, 同时也会增加计算的复杂度, 所以要进行特征选择 (变量选择). 因为要实现直接推力控制, 当然要求推力能被尽快地估计出来, 这就决定了推力估计器要用稀疏最小二乘支持向量回归机进行建模. 以下说明全包线推力估计器的设计过程:




图 2 混合排气涡扇发动机示意图
Fig.2 Illustration of turbofan engine with mixing exhaust

为了减少训练数据的量,同时也为了提高推力的估计精度,现将发动机包线按高度划分为3个区域(Low, Median 和 High),针对每个区域按照 FS 算法进行特征选择,将 45 个可测量压缩为 10 个. 由于这 3 个区域可能选择的特征不尽相同,那么就按照下面 3 个准则进行最后的特征确定:

- ①共性, 尽量选择 3 个区域共有的特征;
- ②可测量性, 尽量选择那些比较容易测量的量(代价小);
- ③专家经验(先验知识), 尽量使选择的量更合理. 最后确定了 7 个量作为推力估计器输入量, 它们是: 高度(H), 马赫数(Ma), 外涵出口总压(p_{16}), 喉道总温(T_8), 主供油量(WFB), 加力供油量(WFA), 发动机温比(ETR). 然后以这 7 个量作为输入量在每一个区域用 Q R SLSSVRM 算法设计一个子推力估计器. 最后用选择器根据当前的飞行状态选择合适的子推力估计器来估计当前航空发动机所提供的推力以便实现直接推力控制.

本文以发动机的稳态数据为研究对象, 在 Low 区域采集了 1 101 个训练数据和 367 个测试数据; 在 Median 区域采集了 1 258 个训练数据和 420 个测试数据; 在 High 区域采集 2018 个训练数据和 673 个测试数据. 在开始训练之前, 将训练数据的输入量进行了归一化处理, 而对输出量推力没有进行归一化处理. 另外, 本文对模型的选择(包括正则化参数 C 和核参数 γ) 采用的是交叉验证法. 定义的一个评估指标为相对误差

相对误差 =
$$\frac{\text{估计值} - \text{实际值}}{\text{实际值}}$$

数字仿真的效果如图 3、4 和 5 所示.




图 3 Low 区域内推力估计的效果

Fig. 3 Estimated effectiveness of thrust in Low region




图 4 Median 区域内推力估计的效果

Fig. 4 Estimated effectiveness of thrust in Median region




图 5 High 区域内推力估计的效果

Fig. 5 Estimated effectiveness of thrust in High region

并将推力估计结果的信息统计于表 1 当中.

由表 1 可知, 用 FS 算法进行特征选择后, 推力估计器相对误差绝对值的最大值为 1.93%, 不超过 2%, 基本上满足了设计直接推力控制器的需求. 并和文献[11] 中的相对误差绝对值的最大值 2.8108% 相比较, 也取得了一定的优势. 从表 1 中每个区域的 1, 2 两行比较可知, 用剪枝算法实现最小二乘支持向量回归机的稀疏性后, 支持向量的数目大大减少, 使预测时间不超过 2 ms(本文的时间是在 Matlab 7.1, CPU 为 AMD3200+ (2 01G), 内存为 512M 的环境下测得的). 对于这个预测时间, 能满足设计直接推力控制器的要求. 另外, 对每个区域的 1, 3 两行进行比较, 可以发现在保持支持向量的数目(# SV) 基本不变的情况下, 用 FS 法进行特征选择后, 预测精度大大提高, 同时, 预测时间也有所减少, 这主要是因为进行特征选择后, 降低了计算量和增强了模型的

表 1 各个区域推力估计结果信息统计

Table 1 Information statistics of thrust estimation results for every region

		$MAX/10^{-3}$	$MIN/10^{-3}$	$STD/10^{-4}$	$MEAN/10^{-5}$	$teTime/ms$	# SV
Low	FS	1.74	-1.36	3.54	1.20	0.3831	84
	-	0.965	-1.58	2.73	0.388	2.9804	392
	-	111	-116	221	-20.7	0.4259	80
Median	FS	1.93	-1.10	3.22	0.152	0.4093	86
	-	1.83	-1.63	2.64	-0.0156	3.0133	367
	-	94.6	-83.1	143	-22.2	0.4836	86
High	FS	1.77	-1.60	2.77	0.903	1.3698	152
	-	1.14	-1.99	1.20	-0.221	8.8921	847
	-	47.3	-43.2	92.5	8.95	1.4627	149

注: MAX 代表估计值的相对误差最大值; MIN 代表相对误差最小值; STD 代表标准差; $MEAN$ 代表相对误差平均值; $teTime$ 代表预测时间; # SV 代表支持向量的数目; FS 代表用 FS 算法进行特征选择; - 代表没有用 FS 算法进行特征选择。

泛化能力. 此外, 在对式(12)进行计算的时候, 如果用一般的协方差法进行计算, 会发现由于条件数太大而造成数值计算的结果极度不稳定, 而用本文所介绍的 QR 方法进行求解, 数字结果是很稳定的, 当然精度也得到提高.

5 结 论

在进行建模前, 如果能进行特征选择, 不仅能降低模型计算的复杂度, 而且还可以增加模型的泛化能力. 然而特征选择问题是一个 NP 难问题, 如果用穷举法, 那是根本不可能也是根本实现不了的. 因此, 本文基于最小二乘支持向量回归机提出了一种 Wrapper 算法, 此算法能对回归问题进行有效的特征选择, 能够增加模型的泛化能力和降低计算的复杂度. 另外, 本文用 QR 算法取代一般的协方差法进行稀疏性建模, 增加了数值的稳定性. 最后, 用本文 FS 算法和 QR-SLSSVRM 算法相结合, 为航空发动机设计了一个直接推力估计器, 数字仿真的效果表明, 此推力估计器能满足实现直接推力控制的需求.

参考文献:

[1] Gastineau Z, Happawana G. Robust model based control for jet engines [R]. AIAA-98-3752, 1998

[2] Maggiore M, Ordonez R, Passino K M, et al. Estimator design in jet engine applications[J]. Engineering Applications of Artificial Intelligence, 2003, 16(7-8): 579-593

[3] Vapnik V N. The nature of statistical theory[M]. New York: Springer-Verlag, 1995

[4] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Process Letter, 1999, 9

(3): 293-300

[5] Suykens J A K, Lukas L, Vandewalle J. Sparse approximation using least squares support vector machines[C] // Proceeding of IEEE International Symposium on Circuits and System, Lausanne, Switzerland: Presses Polytech, Univ. Romandes, 2000: 757-760

[6] Ojeda F, Suykens J A K, Moor B D. Low rank updated LSSVM classifiers for fast variable selection[J]. Neural Networks, 2008, 21(2-3): 437-449

[7] Duda R O, Hart P E, Stork D G. Pattern classification [M]. New York: John Wiley and Sons Inc., 2001.

[8] An S J, Liu W Q, Venkatesh S. Fast cross validation algorithms for least squares support vector machine and kernel ridge regression [J]. Pattern Recognition, 2007, 40(8): 2154-2162

[9] 赵永平, 孙健国. 一类非平坦函数的多核最小二乘支持向量回归机的鲁棒回归算法[J]. 信息与控制, 2008, 37(2): 160-165

ZHAO Yongping, SUN Jianguo. A nonflat function robust regression algorithm using multi kernel LS-SVM[J]. Information and Control, 2008, 37(2): 160-165 (in Chinese)

[10] 赵永平, 孙健国. 一种快速稀疏最小二乘支持向量回归机 [J]. 控制与决策, 2008, 23(12): 1347-1352.

ZHAO Yongping, SUN Jianguo. Fast method for sparse least squares support vector regression machine[J]. Control and Decision, 2008, 23(12): 1347-1352. (in Chinese)

[11] 姚彦龙, 孙健国. 自适应遗传神经网络算法在推力估计器设计中的应用 [J]. 航空动力学报, 2007, 22(10): 1748-1753

YAO Yanlong, SUN Jianguo. Application of adaptive genetic neural network algorithm in design of thrust estimator[J]. Journal of Aerospace Power, 2007, 22(10): 1748-1753 (in Chinese)